

# 다중 분광영상을 이용한 딥러닝 기반 소나무 재선충 피해목 탐색

장 예 예\*, 유 첩\*, 김 동 훈\*, 이 솔 애\*\*, 이 준 환<sup>o</sup>

## Searching Damaged Pine Trees by Wilt Disease Based on Deep Learning Using Multispectral Image

ZHANGRUIRUI\*, YOUJIE\*, Dong-Hoon Kim\*, Sol Ae Lee\*\*, Joonwhoan Lee<sup>o</sup>

### 요 약

소나무 재선충은 한국과 일본, 중국을 포함한 동아시아 지역의 소나무산림에 막대한 피해를 주는 원인이며, 피해목의 조기 발견과 제거는 재선충 확산을 막는 효과적인 방법이다. 본 논문에서는 드론으로 촬영되고 처리된 다중분광 정사영상에서 딥러닝 분류에 의한 재선충 피해목 탐색방법을 제안한다. 제안된 방법은 학습영상 데이터가 많지 않다는 가정 하에서 ResNet18을 백본으로 하는 패치기반의 분류기를 구성하고, 5밴드(RGB, NIR, RedEdge)의 다중 분광 정사영상을 분류하고 그 결과를 heat map 형태로 만든다. 정사영상의 heat map은 후처리를 통해 재선충 피해목의 근사적 위치와 재선충 분포를 통해 확산해가는 모습을 관찰할 수 있게 하며, 피해목 지역의 다중 분광 분포를 추출해낼 수도 있다. 본 연구의 패치기반 분류기 성능은 97.06%의 정확도로 96.50%의 RGB 영상분석 보다는 다소 개선된 결과를 나타내었다.

**Key Words** : pine wilt disease, unmanned aviation vehicle, multispectral ortho-image, deep learning-based classifier, heat map

### ABSTRACT

Wilt disease is a cause of massive damage to pine forests in east Asia including Korea, Japan, and China. One of the effective ways to prevent pine trees from the spread of wilt disease is early detection and removal of damaged trees. This paper proposes a searching method of the damaged pine trees by wilt disease in ortho-images corrected from 5-band multi-spectral images, which are captured by unmanned aviation vehicles. The proposed method constructs patch-based classifier because of the lack of data using ResNet18 backbone network, classifies the 5-band multi-spectral(RGB, NIR, RedEdge) ortho-image patches, and make the results as a heat map. The resulted heat map can be used to find the approximate location and distribution of diseased pine trees to show the trend of spreading disease, and to extract the spectral distribution of the diseased areas in the image. The patch-based classifier with the multispectral images shows 97.06% of accuracy, which is little better than 96.50% with RGB images.

※ 이 논문은 한국국토정보공사/공간정보연구원의 지원을 받아 수행된 연구임 (공간정보연 2019-506).

• First Author : Department of Computer Engineering, Chonbuk National University, ruishaozr@gmail.com, 학생회원

° Corresponding Author : Department of Computer Engineering, Chonbuk National University, chlee@chonbuk.ac.kr, 중신회원

\* Department of Computer Engineering, Chonbuk National University, youjie80@gmail.com, clickmiss123@naver.com

\*\* Pine Wilt Disease Monitoring H/Q-Pest Control Dron Division, Korea Forestry Promotion Institute, solae2@kofpi.or.kr

논문번호 : 202009-220-A-RE, Received September 3, 2020; Revised October 6, 2020; Accepted October 7, 2020

## 1. 서 론

최근 인공지능 딥러닝 모델의 발전에 힘입어 다양한 분야에 인공지능 모델의 적용의 성공사례가 보고되고 있다. 특별히 영상분석 분야에서의 성공은 여러 가지 응용을 가능하게 만들었다.

이들 중에 딥러닝 기반의 항공영상 분석의 정확성은 영상분류, 세그멘테이션, 객체 검출 분야에서 과거의 영상분석방법의 패러다임을 변화시켰을 뿐만 아니라 수 많은 성공적 사례의 등장으로 이어지고 있다. 예로써 광택용 등 은 항공 초분광센서로 취득된 영상으로 토지이용현황(농작물, 건물용도 등)에 CNN(Convolutional Neural Network) 기법을 적용한 분류를 수행한 결과 96% 수준의 높은 정확도가 나타났다<sup>[1]</sup>. 해외의 경우 영농현황 조사는 드론 영상의 주요 응용분야이며, 독일 연구진에서는 딥러닝을 이용하여 드론 영상에서 작물과 잡초를 세그멘테이션 하는 연구를 진행한바 있다<sup>[2]</sup>.

소나무 재선충은 한국과 일본, 중국을 포함한 동아시아 지역의 소나무산림에 막대한 피해를 주는 원인이며, 피해목의 조기 발견과 제거는 재선충 확산을 막는 효과적인 방법이다<sup>[4,5]</sup>.

이에 손민호 등은 2006년에 위성영상을 활용하여 소나무 재선충병 피해지역을 추출하는 기초적인 연구를 실시한바 있다<sup>[6]</sup>. 또한 김명준 등은 2017년 효율적인 예찰 및 방제사업 지원을 실시하기 위해 세종특별자치시를 중심으로 무인항공기를 활용 재선충 선단지에 대하여 무인촬영을 실시 231본의 피해 의심목을 추출하였으며, 현장조사결과 23본의 피해목을 확인하였다. 이 방법에서는 RGB 정사영상을 육안으로 관찰하여 피해 의심목을 2차에 걸쳐 다단계로 검출하였으며 구글, 네이버, 다음 등에서 제공하는 위성영상도 활용하여, 재선충 조사에서 다단계 적용을 통해 산림 내에서의 정확한 위치를 추출하였다<sup>[7]</sup>. 뿐만 아니라 2001년 경일대학교 조명희 등은 경남 거제시 지역을 대상으로 IKONOS 고해상도 위성영상을 분석 총 22개의 샘플중에 15개의 실제 피해목을 추출하였다. 이들은 4m 영상의 R(0.63-0.69) 밴드, NIR(0.76-0.90) 밴드의 히스토그램 분석이 가장 효과적임을 지적하였으며, IKONOS 1m 해상도의 이점과 4m 영상의 다양한 분광 밴드의 장점을 동시에 활용하고 있고 밴드 특징 분석을 수행하여 R, NIR 밴드를 탐색했다<sup>[8]</sup>. 또한 최근에는 2019년 한국임업진흥원은 드론 및 위성 RGB영상을 인공지능 기법으로 분석하여 재선충 피해목 탐지에 성공한 바 있으나 아직 실용적인 결과에는

도달하지 못하였다<sup>[9]</sup>.

본 논문에서는 드론을 통해 획득한 RGB, NIR(Near InfraRed), Red\_Edge 5밴드의 다중 분광영상을 보정하여 얻은 정사영상에서 소나무 재선충 피해목을 탐색하는 방법을 제안한다. 제안된 방법에서는 재선충 피해목의 학습데이터가 불충분하기 때문에 이를 극복하기 위해 정사영상을 패치단위로 분해하여 재선충 패치와 정상 패치를 만들고 패치 단위의 딥러닝 분류기를 학습하여 구성하였다. 구성된 분류기는 정사영상의 패치들을 입력하여 재선충 피해정도를 제공하며 이는 heat map의 형태로 가시화하여 재선충 피해목 정사영상을 만드는데 활용된다.

이렇게 얻은 재선충 피해 정사영상은 후처리를 통하여 재선충의 위치를 근사적으로 파악하는데 활용할 수 있으며, 재선충의 확산경도와 경향을 보여줄 수 있고, 재선충 지역의 다중 분광 분포를 얻는데도 활용될 수 있다.

본 연구의 분류기는 ResNet18을 백본으로 사용하였으며 분류기 정확도는 97.08%에 달하였으며 이는 동일한 방법으로 구성된 RGB 영상분석 96.50% 보다 는 다소 개선된 결과이다.

## II. 제안된 방법

### 2.1 전체 heat map 정사영상 제작과정

그림 1은 본 논문에서 제안하는 패치기반의 재선충 피해목 정사영상 제작과정을 보여 준다. 본 과정은 정사영상이 주어졌다는 가정 하에 진행되며 32×32(너비×높이 픽셀) 패치를 영상에서 순차적으로 뜯어내어 이를 분류기에 입력하고, 학습된 분류기는 softmax 출력으로 재선충 피해목 패치일 확률을 제공하며 그 결과는 heat map으로 나타낸다.

이 과정에서 해상도를 올리기 위해 패치는 중첩되어 뜯어내며 중첩된 부분의 재선충 패치 확률은 평균값을 취해 표시한다.




그림 1. 재선충 피해목 정사영상 제작과정  
Fig. 1. Overall process for constructing the heat map

### 2.2 분류기 구성

본 연구의 분류기는 32×32 패치영상이 재선충 피해 영역을 분별한다. 분류기는 ImageNet 데이터 세트에서 미리 학습된 ResNet18을 (아래 설명과 같이 첫 단을 제외하고) 백본으로 사용하고, 출력은 softmax에 의해 재선충 피해 영역 여부의 확률 값을 출력한다 [10,11].

그림 2는 상대적으로 학습 데이터가 풍부하지 않기 때문에 복잡성이 적절하고 성능이 우수한 ResNet18 layer를 백본으로 사용하는 분류기의 구조를 보여준다.




그림 2. ResNet18을 사용하는 재선충 피해영역 분류기 구조  
Fig. 2. Structure of classifier for damaged area by wilt disease

표 1. ResNet18 구조  
Table 1. Structure of ResNet18


input name	output size	18-layer
input	Multi-bands 5@224×224	7×7, 64, stride 2
	RGB 3@224×224	
	112×112	3×3 max pool, stride 2
Conv2_1	56×56	$(3 \times 3, 64) \times 2$
Conv2_2		
Conv2_3		
Conv2_4		
Conv3_1	28×28	$(3 \times 3, 128) \times 2$
Conv3_2		
Conv3_3		
Conv3_4		
Conv4_1	14×14	$(3 \times 3, 256) \times 2$
Conv4_2		
Conv4_3		
Conv4_4		
Conv5_1	7×7	$(3 \times 3, 512) \times 2$
Conv5_2		
Conv5_3		
Conv5_4		
Average pool	1×1	
Fc	2	softmax

다. 즉 32×32의 RGB, NIR, RedEdge 패치영상은 일단 입력의 크기를 보간법에 의해 확장하여 ResNet18 입력 크기인 224×224 영상으로 확장된다.


표 1과 같이 컨볼루션과 해상도 감소과정을 거치며 2단의 FC(Fully Connected) 레이어를 거쳐 1000차원의 특징으로 만들어지며 이는 최종 softmax 블록에 의해 확률 값으로 변환된다. 여기서 ResNet18은 RGB 영상을 입력으로 첫 번째 컨볼루션 필터는 7×7×3(너비×높이×채널)이다. 본 연구에서는 RGB, NIR, RedEdge 5개의 밴드가 입력이기 때문에 7×7×5로 변경된다.

### 2.3 분류기 구성을 위한 학습데이터 준비 및 학습

본 연구의 학습데이터는 쥘스마트지오에서 제공한 그림 3과 같은 RGB 정사영상의 포함(2018과 2019년), 진주지역의 재선충 피해목을 포함하는 다중 분광 정사영상 데이터를 활용하였다. 그림에서 괄호 안의 내용은 공간해상도를 표현한다. 실제 다중분광 데이터는 딥러닝 학습에 매우 부족하고, 특별히 영상마다 촬영조건 및 다중분광 정사영상 제작과정의 불균일한 영상처리 과정 때문에 영상의 학습영상과 테스트 영상을 분리하기가 어려웠다. 따라서 각 영상을 두 부분으로 나누고 이들 부분에서 학습, 검증(영상의 파랑색 타원)에 사용하는 부분, 테스트(영상의 빨강색 타원)에 사용하는 부분으로 나누었다. 또한 각 영상 및 데이터 밴드의 화소 값을 식 (1)과 같이 밴드별 z-score 값으로 정규화하여 학습에 사용하였다. 식에서  $\mu$ 와  $\sigma$ 는



(a)포항\_2018(23.95cm/화소) (b)포항\_2019(23.68cm/화소)



(c)포항\_2020(21.13cm/화소)

그림 3. 대상지역의 다중분광 정사영상과 정 예제 데이터의 분리  
Fig. 3. Multi-spectral ortho-images and separation of positive examples

표 2. 학습, 검증 및 시험 정 예제 데이터  
Table 2. Positive examples of training, validation and test

number of positive examples	train/valid	test	total
Pohang_2018	128/35	50	213
Pohang_2019	5/0	2	7
Jinju_2020	385/80	85	550
total	518/115	137	770

각각 밴드별 화소 값의 평균과 표준편차를 의미한다.

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

또한 재선충 피해목의 실제 현황은 직접 사람이 접근하여 관측하여 파악해야 한다. 따라서 이런 참값(Ground Truth) 데이터를 다량으로 얻는 것은 많은 노력이 필요한 일이기 때문에 다량의 참값 확보가 불가능하며, 본 연구에서는 NDVI(Normalized Difference Vegetation Index) 영상을 통해 검증된 재선충 피해목 위치를 참값으로 가정(울산 지역)하거나 영상을 전문가가 관측(포항지역)해서 확인한 참값 데이터를 활용하였다.

2.3.1 기하학적 변환에 의한 정 예제의 증강

그림 3의 데이터에서 32×32의 재선충 영역이 중앙에 위치하는 패치영상을 뜯어내 정 예제(positive example)로 하였지만, 정 예제 데이터 수가 많지 않아 본 연구에서는 그림 4와 같이 증강시킴으로써 74,000개의 데이터를 준비하였고, 그 중 60,000개와 14,000개를 각각 학습과 검증 데이터로 활용하였다. 데이터




그림 4. 기하변환과 변위에 의한 정 예제 증강  
Fig. 4. Augmentation of positive example by geometric transform and displacement

증강을 위해 먼저 실제 재선충 피해 위치의 중앙이 400×400 패치영상의 중심에 놓이게 하며, 이를 15도 단위의 회전 변환과 좌우, 상하의 뒤집기(flipping)로 변환하였다. 이렇게 얻은 400×400 영상의 중앙부분에서 32×32 영상을 중첩시켜 5개를 뜯어내어 데이터를 증강하였다. 이는 분류기가 재선충 위치의 변위에 강인하게 분류할 수 있도록 하기 위함이었다. 그림 5(a)는 이렇게 뜯어낸 부분을 예로 보여주고 있다.

본 다중 분광 영상 분석에서는 시각범위 밖의 NIR 및 Red\_Edge 밴드를 포함하기 때문에 RGB 칼라와 같이 각 밴드 별로 지터링하여 정 예제 영상을 증강시키거나, 주성분 분석 후 주성분 방향의 변위를 주어 밴드의 화소 값을 변화시키지는 않았다<sup>[12]</sup>.

2.3.2 부 예제 영상 데이터의 취득

한편 부 예제(negative example) 영상 데이터는 드론 정사영상이 포함하는 도로, 지붕, 숲, 하천 등 다양한 대상을 포함해야 한다. 본 연구에서는 이런 다양성을 유지하기 위해 재선충 피해목 부분을 제외한 부분에서 랜덤하게 74,000개의 32×32 영상패치를 취득하여, 정 예제 데이터와 같이 60,000개와 14,000개를 각각 학습과 검증 데이터로 활용하였다. 일반적으로 데이터 수의 불균등(imbalanced)은 학습에 좋지 않은 영향을 줄 수 있기 때문에 동일한 수의 부 예제 데이터를 구성하였다.

2.3.3 분류기 학습

2.3.2에서 준비된 데이터는 Pytorch로 구성된 분류기 학습하거나 검증하는데 활용된다<sup>[13]</sup>. 본 연구에서는 학습데이터 부족을 극복하기 위하여 ImageNet 데이터 세트로 미리 학습된 백본을 미세 조정한다. 즉 첫 번째 필터를 제외한 구조와 파라메타들을 전달학습에 이용하며, 첫 번째 단의 필터 파라메타는 학습시에 랜덤하게 초기화하였다. 즉 첫 번째 필터의 입력은 RGB 3개의 밴드가 아니라 RGB, NIR, RedEdge 5개의 밴드이기 때문에 해당 네트워크의 파라메타를 랜덤하게 초기화하고, 다른 단의 경우는 기존의 ImageNet 데이터로 미리 학습된 파라메타로부터 학습을 시작하게 하였다.

또한 전술한 바와 같이 ResNet18의 입력크기는 224×224이며, 32×32 영상을 그대로 사용할 경우 크기가 맞지 않기 때문에 이를 224×224 영상으로 bicubic 보간법으로 확장한 영상을 사용한다. 학습율은 0.0001, 모멘텀 0.9, 최적화 도구는 SGD(stochastic gradient descent) 방법을 사용했으며 학습데이터 배

치크기는 200, 검증데이터의 배치는 100으로 설정하였다.

### 2.4 heat map 구성

구성된 분류기는 정사영상의 heat map 구성에 활용된다<sup>[4]</sup>. 다중분광 정사영상으로부터 32×32 패치영상을 좌에서 우로 위에서 아래로 중첩시키며 뜯어내어 분류기를 통해 재선충 피해목 영역일 확률을 구하며, 그 결과를 그림 1에서와 같이 확률 값에 따라 적색에서부터 청색으로 칼라를 선택하게 하였다.

이 과정에서 건너뛰기(stride)는 32일 경우 중첩되는 부분이 없어 32×32 그리드 형태의 모습으로 해상도가 낮은 모습을 보이며, 이를 16, 또는 8로 줄이면 중첩되는 부분이 16, 24가 되어 중첩되는 부분의 확률 결정이 필요하다. 본 연구에서는 중복되어 결정된 확률 값들의 평균치로 각 화소의 확률을 결정하였다. 이렇게 중첩하는 이유는 전체적인 heat map이 연속적으로 변화하는 듯 보일뿐만 아니라, heat map 구성 시 중첩된 부분에서의 평균연산으로 인한 이상불 효과로 분별오류가 완화되는 효과도 기대할 수 있기 때문이다.

## III. 실험 및 결과

본 연구의 정사영상의 해상도는 그림 3에서와 같이 화소 당 21cm-24cm의 5개의 밴드를 가지는 다중분광 정사영상이다.

### 3.1 분류기의 성능평가

본 연구에서는 분류기의 성능을 측정하기 위해 학습과 검증에 사용하지 않은 각 다중분광 정사영상의 부분에서 표 2와 같이 재선충 피해목 지역 137개의 정 예제 영상을 추출하여 학습/검증과 동일한 방법으로 32×32 영상을 14,000개 만들고, 부 영상 데이터는 랜덤하게 32×32 패치영상을 추출해서 이들을 224×224 크기로 bicubic 보간법으로 확장한 후에 분류를 시도하였다. 분류결과의 혼동행렬은 표 2와 같았다. 표에서 괄호 ( )의 내용은 RGB 영상의 결과이다. 이는 정확도

$$\text{정확도} = \frac{TP + TN}{TP + FP + FN + TN} = 97.06\% (95.0\%)$$

에 해당하며

$$\text{재현율} = \frac{TP}{TP + FN} = 98.4\% (97.9\%)$$

$$\text{정도} = \frac{TP}{TP + FP} = 95.6\% (95.0\%)$$

이며,

$$f1 = 2 \cdot \frac{\text{정도} \times \text{재현율}}{\text{정도} + \text{재현율}} = 0.97 (0.94)$$

에 해당한다. 이들 평가결과의 괄호 ( )의 내용은 이 결과는 RGB 영상의 결과로 근소하게 우수한 성능을 보이는 것을 알 수 있다.

당초 다중분광 영상은 NIR 또는 RedEdge의 경우 수분 검출에 감도가 우수하기 때문에 고사목을 검출하는데 유리할 것으로 예상하였다. 그러나 본 실험에 사용한 영상이 늦가을부터 겨울 사이의 영상을 포함하고 있지 않기 때문으로 그 효과가 두드러지지 않은 것으로 판단된다. 즉 활엽수가 갈색으로 변하는 계절에는 RGB 칼라로는 정확한 재선충 피해목 분류가 더 까다롭고, 수분함량 등의 차이를 보다 잘 나타내는 분광영상의 성능이 보다 우수할 것으로 예상되기 때문이다.

표 3. 다중분광 영상 분류기의 혼동행렬


Table 3. Confusion matrix of classifier for multispectral images

truth \ pred	damaged tree images	other images	total
damaged tree images	TP 13,389(13,302)	FN 611(698)	14,000
other images	FP 212(282)	TN 13,788(13,718)	14,000


### 3.2 heat map 구성

그림 2와 같이 분류기를 이용하여 대상 세 지역 중 한 지역의 정사영상에서 학습과 검증에 사용하지 않은 부분의 heat map 정사영상과 의심영역들을 확대한 영상은 그림 5와 같다. 또한 그림 6은 이들 세 정사영상의 heat map에서 900×900의 타일영상을 추출하여 보여주고 있으며, 그림 5와 6은 4×4의 건너뛰기로 heat map을 구성한 결과이다.

그림 5의 전체 정사영상에서 개략적인 재선충 분포를 파악하는데 활용될 수 있으며, 그림 6에서는 비교적 정확한 재선충 피해목의 위치와 분포를 얻어낼 수 있음을 알 수 있다. 즉 그림 5에서는 고속도로를 경계로 재선충이 일렬로 나타나 진행되는 것을 관찰할 수 있으며, 그림 6의 (a)와 (c)에서와 같이 독립된 피해목,



(a) Fig. 3(a)




(b) For Fig. 3(b)

그림 5. Heat map과 부분 확대 영상  
Fig. 5. Heat map and partial magnification


또한 (b)와 (d)에서와 같이 집중된 피해목을 heat map의 형태를 관찰할 수 있다. (그림 6의 각 쌍의 그림의 왼쪽 원 영상에는 실제 참값의 개수가 기입되어 있음) 또한 그림 5의 일렬로 진행되어 나타났던 재선충 피해목이 2019년에는 상당부분 제거되었음에도 영상의 윗부분에 아직도 일부 존재하는 것을 확인할 수 있었다. 즉 재선충 피해목을 일부 제거했다라도 어떤 원인에 의해 남아있는 부분이 있다는 의미이다.

그림 5에서 노란색 원, 또는 6에서 파란색 타원 부분은 실제 도로이거나 바위, 음영지역으로 오검지(FP)가 나타나는 곳을 보여 주고 있다. 이런 오검지는 본 논문의 방법이 실제 재선충 피해목을 자동적으로 찾아내는 데는 한계가 있음을 의미한다. 그러나 실제영상과 heat map 영상을 중첩시키고 이런 오검지들을 전문가가 검증하는 방식으로 반자동화하거나 재선충의 확산 형태를 알아낸다든지, 또는 예찰을 수행하는 데는 도움을 줄 수 있다. 즉 시간의 변화에 따라 다중분광영상을 얻어내고 이를 본 논문의 방법으로 분석하여 변화하는 패턴을 관측하면 재선충 확산 형태를 직관적으로 파악할 수 있으며 그 방향과 속도로부터 일정 부분의 예찰도 가능할 것으로 기대한다.


또한 본 연구의 참값은 NDVI 또는 전문가의 영상 판독을 기반으로 찾은 위치를 이용하기 때문에, 딥러




(a) Spatially separated diseases



(b) Lumped diseases



(c) Spatially separated diseases




(d) Lumped diseases


그림 6. 정사영상의 재선충 부분(붉은색 원과 점)과 heat map 예(파란색 타원은 오검지 부분)  
Fig. 6. Examples of pine wilt diseases in ortho-images(red circles and dots) and heat map(false positives in blue ellipses)

닝 검출 결과가 NDVI 또는 전문가의 결과를 뛰어넘을 수 없으며, 특별히 피해목이 위치하는 침엽수 지역에서 딥러닝 추정 결과는 실제 오검지가 아닐 수도 있다. 즉 ResNet18 분류기의 일반화 능력으로 NDVI로 찾지 못한 참값을 찾았을 가능성도 있기 때문이다.

한편 그림 7에는 그림 6의 비교적 양호한 결과를 보인 (a)와 (c)의 경우 RGB 영상으로부터 얻은 heat map 결과를 보여준다. 그림에서 알 수 있듯이 RGB 영상의 heat map은 상대적으로 덜 분명하거나 오검지 영역이 넓어지는 것을 확인할 수 있어, 다중분광



(a) Multispectral and RGB results of Fig. 6(a)



(b) Multispectral and RGB results of Fig. 6(c)

그림 7. 다중분광 영상 분석과 RGB 영상분석 비교  
Fig. 7. Comparison of results from multispectral and RGB image analysis

영상의 사용이 유리하다는 것을 확인할 수 있다.

#### IV. 결 론

소나무 재선충은 한국과 일본, 중국을 포함한 동아시아 지역의 소나무산림에 막대한 피해를 주는 원인이며, 피해목의 조기 발견과 제거는 재선충 확산을 막는 효과적인 방법이다. 본 논문에서는 드론으로 촬영되고 처리된 다중분광 정사영상에서 딥러닝 분류에 의한 재선충 피해목 탐색방법을 제안하였다. 다중 분광영상은 RGB영상에 비해 상대적으로 데이터 취득이 어렵기 때문에 제안된 방법은 학습영상 데이터가 많지 않다는 가정아래 ResNet18을 백본으로 하는 패치 기반의 분류기를 구성하고 다중 분광 정사영상을 분류하고 그 결과를 heat map 형태로 만든다. 제작된 정사영상의 heat map은 같은 방법으로 실험한 RGB 영상에 비해 재선충 피해목의 분포를 더 분명하게 알아내고 확산해가는 모습을 관찰할 수 있게 하며, 재선충 피해목 지역의 다중 분광 분포 특징을 추출해낼 수도 있다. 본 연구의 패치기반 분류기 성능은 97.06%의 정확도를 나타 내었다. 특별히 다중분광 영상의 경우 데이터 취득이 까다롭기 때문에 본 논문에서 제안하는 패치기반의 분류기를 활용하는 방법이 효과적이며 드론을 이용하는 촬영은 육안판독이 어려운 피해지역 탐색에 도움이 될 것으로 기대한다. 향후에는 더 많은 다중분광 데이터와 실측을 기반으로 하는 참값 데이터를 확보하려 노력이 필요하다. 또한 제안된 방법과 같은 분류결과로 얻어진 heat map으로부터 완전 자동으로 재선충 피해 또는 의심 부문의 찾아내는 방법과 그 정확성을 개선하는 연구를 지속할 예정이다.

#### References

[1] T. Kwak, et al., "The impact of the PCA dimensionality reduction for CNN based hyperspectral Image classification," *Korean J. Remote Sensing*, vol. 35, no. 6, pp. 959-971, 2019.

[2] A. Milioto, P. Lottes, and C. Stachniss, "Real-time semantic segmentation of crop and weed for precision agriculture robots leveraging background knowledge in CNNs," in *Proc. IEEE ICRA*, pp. 2229-2235, Brisbane, Australia, May 2018.

[3] A. Douillar, *Object Detection with Deep*

*Learning on Aerial Imagery*(2018), Retrieved Aug. 31, 2020, from <https://medium.com/data-from-the-trenches/object-detection-with-deep-learning-on-aerial-imagery-2465078db8a9>

[4] Korea Forestry Promotion Institute, *Pine Wilt Disease*, Retrieved Aug. 31, 2020, from [https://www.kofpi.or.kr/intro/bizGuide\\_08\\_02.do](https://www.kofpi.or.kr/intro/bizGuide_08_02.do)

[5] M. Kim, et al., "Early detecting damaged trees by pine wilt disease using DI(Detection Index) from portable near infrared camera," *J. Korean Forestry Soc.*, vol. 100, no. 3, pp. 374-381, 2011.

[6] M. Son, et al., "Natural spread pattern of damaged area by pine wilt disease using geostatistical analysis," *J. Korean Forestry Soc.*, vol. 95, no. 3, pp. 240-249, 2006.

[7] National Institute of Forest Science, *Annual Report of Monitoring for Forest Insect Pests and Diseases in Korea*, p. 57, 2017.

[8] M. Jo, et al., "Extraction method of damaged area by pinetree pest(Bursaphelenchus Xylophilus) using high resolution IKONOS image," *J. Korean Assoc. of Geographic Inf. Stud.*, vol. 4, no. 4, pp. 72-78, 2001.

[9] Maeil Business Newspaper, *Korea Forestry Promotion Institute, Pine wilt disease management with drone AI technology*(2019), Retrieved Aug. 31, 2020, from <https://www.mk.co.kr/news/special-edition/view/2019/08/670046/>

[10] S. J. Pan and Q. Yang, "A survey on transfer learning," *IEEE Trans. Knowledge and Data Eng.*, vol. 22, no. 10, pp. 1345-1359, 2009.

[11] K. He, X. Zhang, S. Ren, et al., "Deep residual learning for image recognition," in *Proc. IEEE Conf. Comput. Vision and Pattern Recognition*, pp. 770-778, Las Vegas, USA, 2016.

[12] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. Big Data*, vol. 6, no. 60, 2019.

[13] A. Paszke, S. Gross, F. Massa, et al., "PyTorch: An imperative style, high-performance deep learning library," in *Proc. Advances in Neural Inf. Process. Sys.*, pp. 8024-8035,

Vancouver, Canada, Dec. 2019.

- [14] M. D. DiFranco, G. O'Hurley, E. W. Kay, et al., "Ensemble based system for whole-slide prostate cancer probability mapping using color texture features," *Computerized Med. Imaging and Graphics*, vol. 35, no. 7-8, pp. 629-645, 2011.

**장 예 예 (ZHANGRUIRUI)**



2012년 : Kunming University of Science and Technology 석사 졸업  
2018년~현재 : 전북대학교 전자정보공학(컴퓨터공학) 박사과정  
<관심분야> 영상처리, 딥러닝


[ORCID:0000-0002-0257-3553]

**유 첩 (YOUJIE)**



2019년 : 전북대학교 전자정보공학(컴퓨터공학) 석사 졸업  
2019년~현재 : 전북대학교 전자정보공학(컴퓨터공학) 박사과정  
<관심분야> 영상처리, 패턴인식, 딥러닝

**김 동 훈 (Dong-Hoon Kim)**



2014년 2월 : 전북대학교 전자정보공학과(컴퓨터공학) 공학사  
2017년 2월 : 전북대학교 전자정보공학과(컴퓨터공학) 공학석사  
2018년 2월~현재 : 전북대학교 전자정보공학과(컴퓨터공학) 박사과정

<관심분야> 영상·음성분석, 감성 인식, 인공지능  
[ORCID:0000-0001-6945-6952]

**이 솔 애 (Sol Ae Lee)**



2013년 2월 : 충남대학교 임산공학과 농학사  
2016년 2월 : 충남대학교 산림자원학과 농학석사  
2016년 9월~현재 : 한국임업진흥원 전임  
<관심분야> 산림병해충, 영상분석, 인공지능

[ORCID:0000-0002-8591-3751]

**이 준 환 (Joonwhoan Lee)**



1980년 2월 : 한양대학교 전자공학과 공학사  
1982년 2월 : 한국과학기술원 전자공학과 공학석사  
1990년 8월 : 미국 미주리대학 전기 및 컴퓨터공학과 공학박사

1990년 10월~현재 : 전북대학교 컴퓨터공학부 교수  
<관심분야> 영상처리, 감성 분석, 인공지능  
[ORCID:0000-0003-1854-9643]